BUNDESREPUBLIK DEUTSCHLAND

CERTIFIED COPY OF PRIORITY DOCUMENT





Prioritätsbescheinigung über die Einreichung einer Patentanmeldung

Aktenzeichen:

101 06 581.7

Anmeldetag:

13. Februar 2001

Anmelder/Inhaber:

Philips Corporate Intellectual Property GmbH, Hamburg/DE

Bezeichnung:

Spracherkennungssystem, Trainingseinrichtung und Verfahren zum iterativen Berechnen freier Parameter

eines Maximum-Entropie-Sprachmodells

IPC:

G 10 L 15/06

Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ursprünglichen Unterlagen dieser Patentanmeldung.

München, den 02. November 2001 Deutsches Patent- und Markenamt Der Präsident

/Im Auftrag





Weihmayr



BESCHREIBUNG

Spracherkennungssystem, Trainingseinrichtung und Verfahren zum iterativen Berechnen freier Parameter eines Maximum-Entropie-Sprachmodells

Die Erfindung betrifft ein Verfahren zum iterativen Berechnen freier Parameter $\lambda_{\alpha}^{ortho(n)}$ eines Maximum-Entropie-Sprachmodells MESM in einem Spracherkennungssystem mit Hilfe des Generalised-Iterative-Scaling-Trainingsalgorithmus gemäß folgender Formel:

$$\lambda_{\alpha}^{ortho(n+1)} = G(\lambda_{\alpha}^{ortho(n)}, m_{\alpha}^{ortho}, \dots)$$
(1)

10 wobei:

n : einen Iterationsparameter;

G: eine mathematische Funktion;

α : ein Merkmal in dem MESM; und

ma ortho

20 -

25

: einen gewünschten orthogonalisierten Randwert in dem MESM für das

15 Merkmal α bezeichnen.

Die Erfindung betrifft weiterhin ein im Stand der Technik bekanntes computerunterstütztes Spracherkennungssystem sowie eine bekannte computerunterstützte Trainingseinrichtung, in denen das beschriebene Verfahren eingesetzt wird.

Ausgangspunkt für die Erstellung eines Sprachmodells, wie es in einem computergestützten Spracherkennungssystem zur Erkennung von eingegebener Sprache verwandt wird, ist eine vordefinierte Trainingsaufgabe. Die Trainingsaufgabe bildet bestimmte statistische Muster in der Sprache eines zukünftigen Benutzers des Spracherkennungssystems in ein System von mathematisch formulierten Randbedingungen ab, welches im allgemeinen folgende Gestalt hat:

$$\sum_{(h,w)} N(h) \cdot p(w|h) \cdot f_{\alpha}(h,w) = m_{\alpha}$$
(2)

wobei:

N(h) : die Häufigkeit der Historie h in einem Trainingskorpus;

P (w | h) : Wahrscheinlichkeit p(w | h), mit welcher sich ein vorgegebenes

Wort wan eine bisherige Wortfolge h (Historie) anschließt;

 $f_{\alpha \text{ (h,w)}}$: eine binäre Merkmalsfunktion für ein Merkmal α ; und

 m_{α} : einen gewünschten Randwert in dem System von

Randbedingungen;

10 bezeichnet.

Die Lösung dieses Systems von Randbedingungen, d.h. der Trainingsaufgabe, wird durch das sogenannte Maximum Entropie Sprachmodell MESM gebildet, welches eine geeignete Lösung des Systems von Randbedingungen in Form einer geeigneten Definition der

15 Wahrscheinlichkeit p(w h) angibt, die wie folgt lautet:

$$p(w \mid h) = p\lambda^{(w \mid h)} = \frac{1}{Z_{\lambda}(h)} \cdot \exp \left(\sum_{\alpha} \lambda_{\alpha} \cdot f_{\alpha}(h, w) \right)$$
(3)

wobei:

25

20 Zλ (h) : einen historienabhängigen Normierungsfaktor;

λα: einen freien Parameter zum Merkmal α;

λ : den Satz aller Parameter

bezeichnen. Für die übrigen Parameter gilt ihre obige Definition.

Die binäre Merkmalsfunktion fα(h,w) trifft beispielsweise eine binäre Entscheidung, ob vorgegebene Worte an bestimmten Stellen in vorgegebenen Wortfolgen h,w enthalten sind.

Ein Merkmal α kann im allgemeinen ein einzelnes Wort, eine Wortfolge, eine Wortklasse (z.B. Farbe oder Verben), eine Folge von Wortklassen oder komplexere Muster bezeichnen.

In Fig. 4 sind vorbestimmte Merkmale in einem Sprachmodell beispielhaft dargestellt. So repräsentieren die dargestellten Unigramme jeweils ein einzelnes Wort, die Bigramme jeweils eine Wortfolge bestehend aus zwei Worten und das abgebildete Trigramm eine Wortfolge bestehend aus drei Worten. Das Bigramm "OR A" schließt das Unigramm "A" ein und umfasst darüber hinaus ein weiteres Wort; es wird deshalb als höher-reichweitig gegenüber dem Unigramm "A" bezeichnet. Analog ist das Trigramm "A WHITE HOUSE" von höherer Reichweite als das Unigramm "HOUSE,, oder als das Bigramm "WHITE HOUSE".

Die freien Parameter λ werden so angepasst, dass Gleichung 3 eine Lösung für das System von Randbedingungen gemäß Gleichung 2 darstellt. Diese Anpassung erfolgt üblicherweise mit Hilfe bekannter Trainingsalgorithmen. Ein Beispiel für einen derartigen Trainigsalgorithmus ist der sogenannte Generalized Iterative Scaling GIS- Algorithmus, wie er z.B. in J.N. Darroch and D. Ratcliff, "Generalized iterative scaling for log linear models, Annals Math. Stat., 43(5):1470-1480, 1972 beschrieben wird.

20

15

Dieser GIS-Algorithmus sieht eine iterative Berechnung der freien Parameter λ vor.

Traditionell erfolgt diese Berechnung allerdings recht langsam. Zur Beschleunigung dieser

Berechnung wird im Stand der Technik vorgeschlagen, die Merkmalsfunktionen f_{α} (h,w)

in dem System von Randbedingungen gemäß Gleichung (2) durch orthogonalisierte

25 Merkmalsfunktionen \int_{α}^{orno} (h,w) zu substituieren; siehe dazu R. Rosenfeld "A maximum entropy approach to adaptice statistical language modelling"; Computer Speech and Language, 10:187-228, 1996.

Mit der Substitution der Merkmalsfunktionen auf der linken Seite in Gleichung 2 ändern

sich allerdings auch die Randwerte m_{α} auf deren rechter Seite. Damit wird das ursprüng-30 liche System von Randbedingungen, d.h. die ursprüngliche Trainingsaufgabe bei den üblichen Ansätzen zum Schätzen der Randwerte verändert; siehe dazu Rosenfeld a.a.O., S. 205, 1.Satz des vorletzten Absatzes.

Es ist insofern als Nachteil des Standes der Technik festzustellen, dass bei der beschleunigten Abwicklung des GIS-Algorithmus die freien Parameter λ auf eine veränderte Trainingsaufgabe trainiert werden. Die auf diese Weise berechneten Parameter λ bewirken bei Einsetzung in Gleichung 3 nur eine unzulängliche Anpassung des Sprachmodells an die ursprüngliche Trainingsaufgabe.

10 Ausgehend von diesem Stand der Technik ist es die Aufgabe der Erfindung, ein bekanntes computergestütztes Spracherkennungssystem, eine computergestützte Trainingseinrichtung und ein bekanntes Verfahren zum iterativen Berechnen freier Parameter λ^{ortho(n)} eines Maximum-Entropie-Sprachmodells in dem Spracherkennungssystem derart weiterzubilden, dass sie eine schnelle Berechnung der freien Parameter λ ohne Veränderung der ursprünglichen Trainingsaufgabe ermöglichen.

Diese Aufgabe wird gemäß Patentanspruch 1 dadurch gelöst, dass bei dem bekannten, einleitend beschriebenen Verfahren zur Berechnung der freien Parameter λ nach dem GIS-Algorithmus jeder gewünschte orthogonalisierte Randwert m_{α}^{ortho} durch Linearkombination des zugehörigen gewünschten Randwertes m_{α} mit gewünschten Randwerten m_{β} von zu dem Merkmal α höher-reichweitigen Merkmalen β berechnet wird. Hierbei sind m_{α} und m_{β} gewünschte Randwerte der ursprünglichen Trainingsaufgabe.

Die Verwendung der so berechneten Randwerte m^{a} ermöglicht vorteilhafterweise eine verbesserte Approximation der freien Parameter λ und damit eine Verbesserung des Sprachmodells im Hinblick auf die ursprüngliche Trainingsaufgabe. Diese qualitative Verbesserung ist möglich bei gleichzeitiger Realisierung einer hohen Konvergenzgeschwindigkeit für die freien Parameter λ bei deren iterativer Berechnung mit Hilfe des GIS-Algorithmus.

20

Die Verwendung der erfindungsgemäß berechneten gewünschten orthogonalisierten Randwerte m_{α}^{ortho} empfiehlt sich für verschiedene Varianten des GIS-Trainingsalgorithmus, wie sie in den Unteransprüchen 12 und 13 beschrieben sind.

Die Aufgabe der Erfindung wird weiterhin durch ein Spracherkennungssystem auf Basis des Maximum Entropie Sprachmodells MESM gemäß Patentanspruch 14 und eine Trainingseinrichtung zum Trainieren des MESM gemäß Patentanspruch 15 gelöst.

Durch Benutzen des erfindungsgemäßen Verfahrens in der Trainingseinrichtung erfolgt eine im Vergleich zum Stand der Technik effektivere Anpassung des MESM in dem Spracherkennungssystem an die individuellen sprachlichen Eigenheiten eines bestimmten Benutzers des Spracherkennungssystems; die Quote mit welcher das Spracherkennungssystem dann die Bedeutungsinhalte in der Sprache des Benutzers richtig erkennt wird wesentlich verbessert.

15

10

Ansonsten entsprechen die Vorteile dieses Spracherkennungssystems und der Trainingseinrichtung den oben für das Verfahren diskutierten Vorteilen.

Der Beschreibung der Erfindung sind folgende Figuren beigefügt, wobei

20

Fig. 1a: ein erfindungsgemäßes Verfahren zur Berechnung

+ 1b

eines gewünschten orthogonalisierten Randwertes m_{α}^{ortho} beschreibt;

Fig. 2a:

ein erfindungsgemäßes Verfahren zur Berechnung

25 + 2b

einer orthogonalisierten Merkmalsfunktion $f_{\,\,{}_{m{lpha}}}$

beschreibt;

Fig. 3 :

ein Blockschaltbild eines erfindungsgemäßen Spracherkennungssystems;

und

Fig. 4: einen Merkmalsbaum beschreibt.

5

Es erfolgt im weiteren zunächst eine detaillierte Beschreibung eines Ausführungsbeispiels der Erfindung unter Bezugnahme auf die Fig. 1a und 1b.

Die Fig. 1a und 1b veranschaulichen ein erfindungsgemäßes Verfahren zum Berechnen eines verbesserten gewünschten orthogonalisierten Randwertes m_{α}^{ortho} für ein Merkmal $\alpha = \beta 0$ in einem Sprachmodell. In einem ersten Verfahrens-schritt S1 werden gemäß diesem Verfahren alle in dem Sprachmodell definierten Merkmale β i mit i = 1 ... g bestimmt, welche eine sog. höhere Reichweite aufweisen als das vorbestimmte Merkmal $\alpha = \beta 0$, d.h. welche dieses an einer vorbestimmten Stelle einschließen. Anschließend wird in einem Verfahrensschritt S2 für alle Merkmale β i mit i = 0 ... g, also auch für das Merkmal $\alpha = \beta 0$, ein gewünschter Randwert m β i der ursprünglichen Trainingsaufgabe berechnet.

Für die Berechnung eines solchen gewünschten Randwertes mβi sind verschiedene Methoden im Stand der Technik bekannt.

Gemäß einer ersten Methode erfolgt die Berechnung dadurch, dass zunächst eine Häufig20 keit N(\(\beta\)i) ermittelt wird, mit welcher die zugehörige binäre Merkmalsfunktion f\(\beta\)i bei
Anwendung auf einem Trainingskorpus des Sprachmodells den Wert 1 ergibt und dass
anschließend der so ermittelte Häufigkeitswert N(\(\beta\)i) geglättet wird.

Gemäß einer zweiten alternativen Methode erfolgt die Berechnung durch Reduktion von

Merkmalsmengen in dem Sprachmodell so lange, bis die Randbedingungen keine Widersprüche mehr aufweisen. Eine derartige Reduktion von Merkmalsmengen muss in der
Praxis sehr umfangreich sein, weil ansonsten das erzeugte Sprachmodell keine Lösung mehr
zu der ursprünglichen Trainingsaufgabe darstellt.

Gemäß einer dritten Methode erfolgt die Berechnung durch Benutzung eines sogenannten induzierenden Sprachmodells, wie es in J.Peters und D.Klakow, "Compact Maximum Entropy Language Models", Proc. ASRU, Keystone, Colorado, 1999 beschrieben ist.

In einem Verfahrensschritt S3 werden nachfolgend alle Merkmale βi nach ihrer Reichweite sortiert, wobei einem Merkmal βi mit der größten Reichweite der Index i = g zugeordnet wird. Dabei kann es durchaus vorkommen, dass einzelnen Reichweitenklassen, also z.B. der Klasse Bigramme oder der Klasse Trigramme, mehrere Merkmale βi zugeordnet werden. In diesen Fällen sind mehrere Merkmale βi mit unterschiedlichen, aber aufeinanderfolgenden Indizes i ein und derselben Reichweitenklasse zugeordnet, d.h. diese Merkmale haben dann jeweils dieselbe RW und gehören derselben Reichweitenklasse an.

Für den Ablauf des Verfahrens, bei welchem in den nachfolgenden Schritten die einzelnen Merkmale βi der Reihe nach ausgewertet werden, ist es wichtig, dass die Merkmale nach absteigender (oder gleichbleibender) Reichweite abgearbeitet werden. Im ersten Durchlauf des Verfahrens wird daher mit einem Merkmal βi begonnen, welches der höchsten Reichweitenklasse zugeordnet ist; vorzugsweise wird i = g gesetzt (siehe Verfahrensschritte S4 und S5 in Fig. 1a).

10

15

20

25

30

In einem nachfolgenden Verfahrensschritt S6 wird geprüft, ob es zu dem aktuell ausgewählten Merkmal β i höher- reichweitige Merkmale β k mit i < k \leq g gibt, welche das Merkmal β i einschließen. Beim ersten Durchlauf gehört das Merkmal β i mit i=g, wie oben gesagt, automatisch der Klasse mit der höchsten Reichweite an und deshalb ist die Abfrage in Verfahrensschritt S6 für dieses Merkmal β i zu verneinen. In diesem Fall springt das Verfahren zu Verfahrensschritt S8, wo ein Parameter X zu Null gesetzt wird. Es erfolgt daraufhin eine Berechnung eines verbesserten gewünschten orthogonalisierten Randwertes m_{β}^{ortho} für das Merkmal β i (beim ersten Durchlauf mit i=g) gemäß Verfahrensschritt S9. Wie dort ersichtlich, wird dieser Randwert für das Merkmal β i dem in Schritt S2 berechneten gewünschten Randwert m β i gleichgesetzt, wenn der Parameter X=0 ist (dies ist z.B. beim ersten Durchlauf der Fall).

Die Verfahrensschritte S5 bis S11 werden daraufhin sukzessive für alle Merkmale βi-1 mit i-1 = g-1 ... 0 wiederholt. In Verfahrensschritt S10 findet eine dafür notwendige Neuinitialisierung des Indexes i statt und in Verfahrensschritt S11 erfolgt eine Abfrage, ob alle

Merkmale \(\beta i \) mit i = 0 ... g abgearbeitet worden sind.

Für alle Merkmale βi, für welche höher-reichweitige Merkmale βk mit i < k ≤ g existieren, ist die Abfrage in Verfahrensschritt S6 mit "Ja" zu beantworten. Der Parameter X wird dann nicht zu Null gesetzt, sondern berechnet sich gemäß Verfahrensschritt S7 durch Aufsummierung der entsprechenden, in vorherigen Durchläufen jeweils in Verfahrensschritt S9 berechneten verbesserten gewünschten orthogonalisierten Randwerten morthogonalisierten Randwerten die jeweils höher-reichweitigen Merkmale βk.

Sobald in Verfahrensschritt S11 festgestellt worden ist, dass der gewünschte orthogonalisierte Randwert $m_{\beta 0}^{ortho}$ in Verfahrensschritt S9 berechnet worden ist, wird dieser in Verfahrensschritt S12 als m_{α}^{ortho} ausgegeben.

Das soeben ausführlich beschriebene erfindungsgemäße Verfahren zur Berechnung des verbesserten gewünschten orthogonalisierten Randwertes m_{α}^{ortho} lässt sich in Kurzschreibweise gemäß folgender Formel zusammenfassen:

$$m_{\alpha}^{ortho} = m\alpha - {N \choose \beta} m_{\beta}^{ortho}$$
 (4)

Die Summe (*) umfasst alle höher-reichweitigen Merkmale β, welche das vorbestimmte Merkmal α einschließen. Zur Berechnung des Randwertes m_{β}^{ortho} ist die genannte Formel quasi rekursiv für jedes Merkmal β immer wieder anzuwenden, bis für bestimmte Merkmale, nämlich jene mit der höchsten Reichweite, der Summenterm verschwindet, weil zu diesen Merkmalen keine höher-reichweitigen existieren. Die gewünschten orthogonalisierten Randwerte für die höchstreichweitigen Merkmale βk entsprechen dann jeweils den ursprünglichen gewünschten Randwerten mβk.

Die Anwendung des erfindungsgemäßen Verfahrens gemäß den Fig. 1a und 1b soll nachfolgend durch Anwendung auf dem folgenden beispielhaften Trainingskorpus eines

NU

Sprachmodells erläutert werden. Der Trainingskorpus lautet:

"THAT WAS A RED

OR A GREEN HOUSE

OR A BLUE HOUSE

THIS IS A WHITE HOUSE AND

THAT IS THE WHITE HOUSE"

Das Trainingskorpus besteht aus N = 23 einzelnen Worten. Es sei vorausgesetzt, dass in dem Sprachmodell die gewünschten Unigramm-, Bigramm- und Trigramm-Merkmale gemäß Fig. 4 vordefiniert sind.

Es kann dann durch Anwendung der normalen Merkmalsfunktion fα auf das Trainingskorpus festgestellt werden, dass die Unigramme, Bigramme und Trigramme gemäß Fig. 4 mit folgenden Häufigkeiten in dem Trainingskorpus vorhanden sind:

Unigramme:

	Α	4
20	HOUSE	4
	IS	. 2
	OR	2
	THAT	2
	WHITE	2

25

15

5

Bigramme:

A WHITE 1
OR A 2
WHITE HOUSE 2

30

Trigramme:

A WHITE HOUSE 1

In dem hier gezeigten Beispiel soll der verbesserte gewünschte orthogonalisierte Randwert m_{α}^{ortho} für das Merkmal α = "HOUSE" berechnet werden. Dafür sind zunächst gemäß Verfahrensschritt S1 in Fig. 1a alle zu dem Merkmal α höher-reichweitigen Merkmale zu bestimmen. Es sind dies gemäß Fig. 4 das Bigramm "WHITE HOUSE" und das Trigramm "A WHITE HOUSE". Gemäß Verfahrensschritt S2 sind nun für diese höherreichweitigen Merkmale, aber auch für das Merkmal α die normalen gewünschten Randwerte zu berechnen, z.B. indem die jeweiligen, oben festgestellten Häufigkeiten geglättet werden. Diese Glättung erfolgt hier beispielhaft durch Subtraktion des Wertes 0,1. Damit ergeben sich folgende normale gewünschte Randwerte:

10

 $m\alpha$: "HOUSE" = 4 - 0,1 = 3,9

 $m\beta 1$: "WHITE HOUSE" = 2 - 0,1 = 1,9

15 m β 2 : "A WHITE HOUSE" = 1 - 0,1 = 0,9.

Die Merkmale α , β_1 , β_2 werden nun ihrer Reichweite nach sortiert und es werden beginnend mit dem längst- reichweitigen Merkmal - die jeweiligen verbesserten gewünschten orthogonalisierten Randwerte gemäß Formel (6) bzw. gemäß Verfahrensschritt S7 - S9 in Fig. 1a und 1b berechnet:

$$m_{\beta 2}^{ortho} = m_{\beta 2} \qquad \qquad = 0,9 \tag{5}$$

$$m_{\beta 1}^{ortho} = m_{\beta 1} - m_{\beta 2}^{ortho} = 1,9 - 0,9 = 1$$
 (6)

25

20

Schließlich berechnet sich der verbesserte gewünschte orthogonalisierte Randwert m_{α}^{ortho} für das Merkmal α zu:

$$m_{\alpha}^{ortho} = m_{\alpha} - m_{\beta 1}^{ortho} - m_{\beta 2}^{ortho} = 3,9 - 1 - 0,9 = 2$$
 (7)

Der so erfindungsgemäß berechnete orthogonalisierte Randwert m_{α}^{ortho} ermöglicht eine ausreichend genaue Berechnung der freien Parameter λ und damit der Wahrscheinlichkeit gemäß Formel (1) im Hinblick auf eine ursprüngliche Trainingsaufgabe bei gleichzeitig großer Rechengeschwindigkeit bei Verwendung in dem GIS-Trainingsalgorithmus.

5

Nachfolgend wird die Verwendung des erfindungsgemäß berechneten Randwertes m_{α}^{ortho} für drei unterschiedliche Varianten des GIS-Trainingsalgorithmus dargestellt.

10

Bei einer ersten Variante des GIS-Trainingsalgorithmus hat die mathematische Funktion G gemäß Gleichung 1 bei Verwendung des erfindungsgemäß berechneten orthogonalisierten Randwertes m_{α}^{ortho} folgende Gestalt:

$$\lambda_{\alpha}^{ortho(n+1)} = G(\lambda_{\alpha}^{ortho(n)}, m_{\alpha}^{ortho}, \dots)$$

$$= \lambda_{\alpha}^{ortho(n)} + t_{\alpha}^{ortho} \cdot \log \left[\frac{\left[t_{\alpha}^{ortho} \cdot m_{\alpha}^{ortho} + b_{\alpha} \right]}{\left[t_{\alpha}^{ortho} \cdot m_{\alpha}^{ortho(n)} + b_{\alpha} \right]} \cdot \frac{1 - \sum_{\gamma} \left[t_{\gamma}^{ortho} \cdot m_{\gamma}^{ortho(n)} + b_{\gamma} \right]}{1 - \sum_{\gamma} \left[t_{\gamma}^{ortho} \cdot m_{\gamma}^{ortho} + b_{\gamma} \right]} \right]$$
(8)

15 wobei:

n

einen Iterationsparameter;

α

ein gerade betrachtetes Merkmal;

v

alle Merkmale in dem Sprachmodell;

 t_{ν}^{ortho}

die Größe eines Konvergenzschrittes;

mortho mortho

gewünschte orthogonalisierte Randwerte in dem MESM für die

Merkmale α und γ ;

 $m_{\alpha}^{ortho(n)}$ $m_{\gamma}^{ortho(n)}$

: iterative Näherungswerte für die

gewünschten Randwerte

25

 m_{α}^{ortho} , m_{γ}^{ortho} ; und

bα und by

Konstanten

bezeichnen.

10

25

Die Berechnung der Konvergenzschrittgrößen t und der iterativen Näherungswerte für die gewünschten Randwerte m erfolgt - wie nachfolgend gezeigt wird - durch Verwendung einer erfindungsgemäß definierten orthogonalisierten Merkmalsfunktion f_{α}^{ortho} , welche wie folgt lautet:

$$f_{\alpha}^{ortho} = f\alpha - {*}^{(*)} f_{\beta}^{ortho}$$
(9)

Es sei an dieser Stelle betont, dass die gemäß Gleichung 9 erfindungsgemäß berechnete orthogonale Merkmalsfunktion f_{α}^{ortho} in ihrem Betrag der von Rosenfeld a.a.O. vorgeschlagenen Merkmalsfunktion entspricht. Allerdings erfolgt ihre erfindungsgemäße

Berechnung, wie in den Fig. 2a und 2b veranschaulicht, gänzlich anders. Das Berechnungsverfahren läuft analog ab zu dem in den Fig. 1a und 1b beschriebenen Verfahren zur Berechnung der gewünschten orthogonalisierten Randwerte m_{α}^{ortho} , wobei lediglich das Symbol für den Randwert m durch das Symbol für die Merkmalsfunktion f und der Parameter X durch die Funktion F zu ersetzen ist. Um Wiederholungen zu vermeiden, wird an dieser Stelle für Erläuterungen des Verfahrens gemäß Fig. 2a und 2b auf die Beschreibung der Fig. 1a und 1b verwiesen.

Mit der so erfindungsgemäß berechneten orthogonalisierten Merkmalsfunktion f_{α}^{ortho} bzw. f_{β}^{ortho} berechnet sich die Größe der Konvergenzschritte t_{α}^{ortho} und t_{γ}^{ortho} in Gleichung 8 wie folgt:

$$t_{\alpha}^{ortho} = t_{\gamma}^{ortho} = 1/M^{ortho} \quad \text{mit} \quad M^{ortho} = \max_{(h,w)} \left(\sum_{\beta} f_{\beta}^{ortho}(h,w) \right)$$
(10)

wobei Mortho für binäre Merkmalsfunktionen f_{β}^{ontho} die maximale Anzahl von Funktionen repräsentiert, welche für dasselbe Argument (h,w) den Wert 1 liefern.

Weiterhin berechnet sich mit der erfindungsgemäß definierten Merkmalsfunktion f_{α}^{ortho} der iterative Näherungswert $m_{\alpha}^{ortho(n)}$ für den gewünschten orthogonalisierten Randwert m_{α}^{ortho} bei analoger Anwendung der Gleichung (2) wie folgt:

$$m_{\alpha}^{ortho(n)} = \sum_{(h,w)} N(h) \cdot p^{(n)}(w \mid h) \cdot f_{\alpha}^{ortho}(h,w)$$

$$; \tag{11}$$

10 wobei:

N(h) : die Häufigkeit der Historie h im Trainingskorpus; und

 $p^{(n)}(w|h)$: einen Iterationswert für die Wahrscheinlichkeit p(w|h), mit welcher sich ein vorgegebenes Wort wan eine bisherige Wortfolge h (Historie)

anschließt;

15

bezeichnet. Hierbei benutzt $p^{(n)}(w|h)$ die Parameterwerte $\lambda_{\alpha}^{ortho(n)}$.

Die Verwendung des erfindungsgemäß berechneten verbesserten gewünschten orthogonalisierten Randwertes m_{α}^{ortho} empfiehlt sich weiterhin für eine zweite Variante des GISTrainingsalgorithmus. Hierbei sind die Merkmale des MESM in m Gruppen Ai aufgeteilt, und pro Iteration werden nur die Parameter λ_{α}^{ortho} der Merkmale α aus einer der Gruppen gemäß der folgenden Formel verändert:

$$\lambda_{\alpha}^{ortho(n+1)} = G(\lambda_{\alpha}^{ortho(n)}, m_{\alpha}^{ortho}, \dots)$$

$$= \lambda_{\alpha}^{ortho(n)} + t_{\alpha}^{ortho} \cdot \log \left(\frac{m_{\alpha}^{ortho}}{m_{\alpha}^{ortho(n)}} \cdot \frac{1 - \sum_{\beta \in Ai(n)} (t_{\beta} \cdot m_{\beta}^{ortho(n)})}{1 - \sum_{\beta \in Ai(n)} (t_{\beta} \cdot m_{\beta}^{ortho})} \right)$$
(12)

wobei:

n : der Iterationsparameter

Ai(n) : eine in dem n'ten Iterationsschritt ausgewählte

5 Merkmalsgruppe Ai(n) mit $1 \le i \le m$;

α : ein gerade betrachtetes Merkmal aus der gerade

ausgewählten Merkmalsgruppe Ai(n);

β : alle Merkmale aus der Merkmalsgruppe Ai(n);

 t_a^{ortho} , t_{β}^{orno} : die Größe eines Konvergenzschrittes mit

 $t_{\alpha}^{ortho} = t_{\beta}^{ortho} = 1/M_{i(n)}^{ortho}$ mit

 $M_{i(n)}^{ortho} = \max_{(h,w)} \left(\sum_{\beta \in Ai(n)} f_{\beta}^{ortho}(h,w) \right)$

wobei

 $M_{i(n)}^{ortho}$ für binäre Funktionen f_{β}^{ortho} die maximale Anzahl von Funktionen aus der Merkmalsgruppe Ai(n) repräsentiert, welche für dasselbe Argument (h,w) den Wert 1 liefern;

 m_{α}^{ortho} m_{β}^{ortho}

gewünschte orthogonalisierte Randwerte in dem MESM für die Merkmale α bzw. β ;

 $m_{\alpha}^{ortho(n)}$ $m_{\beta}^{ortho(n)}$

iterative Näherungswerte für die gewünschten Randwerte

 m_{α}^{ortho} , m_{β}^{ortho} ;

20

15

10

Die Gruppe Ai(n) von Merkmalen α , deren Parameter λ_{α}^{ortho} im aktuellen Iterationsschritt angepasst werden, durchläuft dabei zyklisch gemäß i(n)=n(mod m) alle m Gruppen.

Die Verwendung des erfindungsgemäß berechneten gewünschten orthogonalisierten

Randwertes m_{α}^{ortho} empfiehlt sich weiterhin für eine dritte Variante des GIS-Trainingsalgorithmus, welche sich von der zweiten Variante lediglich dadurch unterscheidet, dass die bei jedem Iterationsschritt zu verwendende Merkmalsgruppe Ai(n) nicht zyklisch, sondern

nach einem vorbestimmten Kriterium $D_i^{(n)}$ ausgewählt wird.

15

20

25

30

In Fig. 3 ist schließlich ein Spracherkennungssystem 10 gemäß der vorliegenden Erfindung dargestellt, welches auf Basis des sog. Maximum-Entropie-Sprachmodells arbeitet. Es umfasst eine Erkennungseinrichtung 12, welche den Bedeutungsinhalt von bereitgestellten Sprachsignalen zu erkennen versucht. Die Sprachsignale werden dem Spracherkennungssystem üblicherweise als Ausgangssignale eines Mikrophons 20 bereitgestellt. Die Erkennungseinrichtung 12 erkennt den Bedeutungsinhalt der Sprachsignale dadurch, dass sie Muster in dem empfangenen akustischen Signal auf vordefinierte Erkennungssymbole, wie z.B. bestimmte Worte, Handlungen oder Ereignisse, mit Hilfe des implementierten Maximum Entropie Sprachmodells MESM abbildet. Schließlich gibt die Erkennungseinrichtung 12 ein Ausgangssignal aus, welches den in dem Sprachsignal erkannten Bedeutungsinhalt repräsentiert und zur Ansteuerung von verschiedensten Geräten, z.B. eines Textverarbeitungsprogramms oder eines Telefons nach Maßgabe durch diesen Bedeutungsinhalt dienen kann.

Für eine möglichst fehlerfreie Ansteuerung der Geräte im Sinne des Bedeutungsinhaltes von steuernder Sprachinformation ist es erforderlich, dass das Spracherkennungssystem 10 die Bedeutungsinhalte der auszuwertende Sprache mit einer möglichst hohen Quote richtig erkennt. Dazu ist eine möglichst gute Anpassung des Sprachmodells an die sprachlichen Besonderheiten des Sprechers, d.h. des Benutzers des Spracherkennungssystems erforderlich. Diese Anpassungsaufgabe leistet eine Trainingseinrichtung 14, welche entweder extern oder in das Spracherkennungssystem 10 integriert betrieben werden kann. Genauer gesagt dient die Trainingseinrichtung 14 zum Anpassen des MESM in dem Spracherkennungssystem 10 an wiederkehrende statistische Muster in der Sprache eines bestimmten Benutzers.

Sowohl die Erkennungseinrichtung 12 wie auch die Trainingseinrichtung 14 sind üblicherweise, aber nicht notwendigerweise, als Softwaremodule ausgebildet und laufen auf einem geeigneten Computer (nicht gezeigt) ab.

7/

<u>PATENTANSPRÜCHE</u>

1. Verfahren zum iterativen Berechnen freier Parameter $\lambda_a^{ortho(n)}$ eines Maximum-Entropie-Sprachmodells MESM mit Hilfe des Generalised-Iterative-Scaling-Trainingsalgorithmus gemäß folgender Formel:

$$\lambda_{\alpha}^{ortho(n+1)} = G(\lambda_{\alpha}^{ortho(n)}, m_{\alpha}^{ortho}, \ldots)$$

wobei:

5

: einen Iterationsparameter;

G: eine mathematische Funktion;

10 α : ein Merkmal in dem MESM; und

ortho

: einen gewünschten orthogonalisierten Randwert in dem MESM für das

Merkmal α;

dadurch gekennzeichnet,

dass der gewünschte orthogonalisierte Randwert m_{α}^{ortho} durch Linearkombination des

- 15 gewünschten Randwertes m_{α} mit gewünschten Randwerten m_{β} von zu dem Merkmal α höher-reichweitigen Merkmalen β berechnet wird.
 - 2. Verfahren nach Anspruch 1, dadurch gekennzeichnet,
- dass die Berechnung des gewünschten orthogonalisierten Randwertes m_{α}^{ortho} für das Merkmal α = β 0 folgende Schritte umfasst:

- a) Auswählen aller Merkmale β i mit i=1...g in dem Sprachmodell, welche eine höhere Reichweite RW aufweisen als das Merkmal α = β 0 und dieses jeweils einschließen;
- b) Berechnen von gewünschten Randwerten mßi für die Merkmale ßi mit i=0...g;
- 5 c) Sortieren der Merkmale βi mit i= 0...g nach ihrer RW;
 - d) Auswahl eines der Merkmale Bi mit der höchsten RW;
- e) Prüfen, ob es zu dem ausgewählten Merkmal βi andere Merkmale βk höherer RW gibt, 10 welche das Merkmal βi einschließen;
 - f1) Wenn ja, dann Definieren eines Parameters X als Linearkombination der beim letzten Durchlauf der Schritte e) bis g) in Schritt g) berechneten orthogonalisierten Randwerte m_{jk}^{ortho} für alle im zuletzt ausgeführten Schritt e) bestimmten höher-reichweitigen Merkmale βk ;
 - f2) Wenn nein, dann Definieren des Parameters X zu X = 0;

- g) Berechnen des gewünschten orthogonalisierten Randwertes mβi für das Merkmal βi
 durch arithmetisches Verknüpfen des gewünschten Randwertes mβi mit dem Parameter X;
 und
 - h) Wiederholen der Schritte e) bis g) für das Merkmal
 - βi-1, dessen RW kleiner oder gleich der RW des Merkmals βi ist, solange bis der
- gewünschte orthogonalisierte Randwert $m_{\beta 0}^{ortho} = m_{\alpha}^{ortho}$ mit i=0 in Schritt g) berechnet worden ist.

3. Verfahren nach Anspruch 2,

dadurch gekennzeichnet,

dass die Berechnung des Parameters X in Schritt f1) gemäß folgender Formel erfolgt:

$$X = \sum_{k} m_{\beta k}^{ortho}$$

5

10

4. Verfahren nach Anspruch 3, dadurch gekennzeichnet,

dass die Berechnung des gewünschten orthogonalisierten Randwertes $m_{\beta i}^{ortho}$ in Schritt g) gemäß der folgenden Formel erfolgt:

$$m_{\beta}^{ortho} = m_{\beta} - X$$

15 5. Verfahren nach Anspruch 2, dadurch gekennzeichnet,

dass die Berechnung von gewünschten Randwerten $m_{\beta i}$ für die Merkmale βi mit i=0,...,g in Schritt b) durch jeweiliges Berechnen der Häufigkeit N(βi), mit welcher das Merkmal β i in einem Trainingskorpus enthalten ist, und durch nachfolgendes Glätten des



20 berechneten Häufigkeitswertes N(βi) erfolgt.

6. Verfahren nach Anspruch 5,

dadurch gekennzeichnet,

dass die Berechnung der Häufigkeit N(\(\beta\)i) durch Anwenden einer bin\(\text{aren}\)
Merkmalsfunktion f\(\beta\)i auf den Trainingskorpus erfolgt, wobei f\(\beta\)i definiert ist als:

5

$$f_{\beta}(h, w) = \begin{cases} 1 \text{ falls } \beta_i \text{ zur Wortfolge (h, w) passt} \\ 0 \text{ sonst} \end{cases}$$

und wobei $f_{\beta i}(h, w)$ eine Aussage darüber macht, ob das Merkmal β i ein durch die Wortfolge (h,w) vorgegebenes Muster richtig beschreibt.

10

7. Verfahren nach Anspruch 1,

dadurch gekennzeichnet,

dass die mathematische Funktion G als weitere Variable die Größe eines

Konvergenzschrittes t_{α}^{ortho} mit

$$t_{\alpha}^{\text{ortho}} = 1/M^{\text{ortho}}$$

15

aufweist, wobei

Mortho: für binäre Funktionen fan die maximale Anzahl von Funktionen repräsentiert, welche für dasselbe Argument (h,w) den Wert 1 liefern.

20

25

8. Verfahren nach Anspruch 7,

dadurch gekennzeichnet,

dass die Merkmalsfunktion f_{α}^{ortho} durch Linearkombination einer Merkmalsfunktion f_{α} mit orthogonalisierten Merkmalsfunktionen f_{β}^{ortho} von zu dem Merkmal α höherreichweitigen Merkmalen β berechnet wird.

9. Verfahren nach Anspruch 8, dadurch gekennzeichnet,

dass die Berechnung der orthogonalisierten Merkmalsfunktion f_{α}^{onho} für das Merkmal α = β 0 folgende Schritte umfasst:

5

- a) Auswählen aller Merkmale βi mit i=1...g in dem Sprachmodell, welche eine höhere Reichweite RW aufweisen als das Merkmal α=β0 und dieses jeweils einschließen;
- b) Berechnen von Merkmalsfunktionen f\u00e4i f\u00fcr die Merkmale \u00dfi mit i=0...g;

10

- c) Sortieren der Merkmale ßi mit i= 0...g nach ihrer RW;
- d) Auswahl eines der Merkmale ßi mit der höchsten RW;
- e) Prüfen, ob es zu dem ausgewählten Merkmal βi andere Merkmale βk höherer RW gibt, welche das Merkmal βi einschließen;
 - f1) Wenn ja, dann Definieren einer Funktion F als Linearkombination der beim letzten Durchlauf der Schritte e) bis g) in Schritt g) berechneten orthogonalisierten
- 20 Merkmalsfunktion $f_{\beta k}^{ortho}$ für alle im zuletzt ausgeführten Schritt e) bestimmten höherreichweitigen Merkmale βk ;
 - f2) Wenn nein, dann Definieren der Funktion F zu F = 0;
- g) Berechnen der orthogonalisierten Merkmalsfunktion f_{β}^{ortho} für das Merkmal β i durch arithmetisches Verknüpfen der Merkmalsfunktion β i mit der Funktion β ; und
 - h) Wiederholen der Schritte e) bis g) für das Merkmal βi-1, dessen Reichweite kleiner oder

- 21 -

24

gleich der Reichweite des Merkmals β i ist, solange bis die orthogonalisierte Merkmalsfunktion $f_{\beta 0}^{ortho} = f_{\alpha}^{ortho}$ mit i=0 in Schritt g) berechnet worden ist.

10. Verfahren nach Anspruch 9,

5 dadurch gekennzeichnet,

dass die Berechnung der Funktion F in Schritt f1) gemäß folgender Formel erfolgt:

$$F = \sum_{k} f_{\beta k}^{ortho}$$

10 11. Verfahren nach Anspruch 9, dadurch gekennzeichnet,

dass die Berechnung der orthogonalisierten Merkmalsfunktion $f_{\beta i}^{ortho}$ in Schrittg) gemäß der folgenden Formel erfolgt:

$$f_{\beta}^{ortho} = f_{\beta} - F$$

12. Verfahren nach Anspruch 1, dadurch gekennzeichnet,

dass die mathematische Funktion G folgende Gestalt hat:

$$\lambda^{ortho(n+1)} = G(\lambda^{ortho(n)} m^{ortho(n)})$$

$$= \lambda_{\alpha}^{ortho(n)} + t_{\alpha}^{ortho} \cdot \log \left(\frac{\left[t_{\alpha}^{ortho} \cdot m_{\alpha}^{ortho} + b_{\alpha} \right]}{\left[t_{\alpha}^{ortho} \cdot m_{\alpha}^{ortho(n)} + b_{\alpha} \right]} \cdot \frac{1 - \sum_{\gamma} \left[t_{\gamma}^{ortho} \cdot m_{\gamma}^{ortho(n)} + b_{\gamma} \right]}{1 - \sum_{\gamma} \left[t_{\gamma}^{ortho} \cdot m_{\gamma}^{ortho} + b_{\gamma} \right]} \right)$$

wobei:

20

α : ein gerade betrachtetes Merkmal;

25 γ : alle Merkmale in dem Sprachmodell;

 t_{α}^{ortho} t_{γ}^{ortho}

: die Größe eines Konvergenzschrittes mit $t_{\alpha}^{ortho} = t_{\gamma}^{ortho} = 1/M^{ortho}$ mit

$$M^{ortho} = \max_{(h,w)} \left(\sum_{\beta} f_{\beta}^{ortho}(h,w) \right)$$

wobei Mortho für binäre Funktionen f_{β}^{ortho} die maximale Anzahl von Funktionen repräsentiert, welche für dasselbe Argument (h,w) den Wert 1 liefern;

5.

 $m_{\alpha}^{ortho} m_{\gamma}^{ortho}$

: gewünschte orthogonalisierte Randwerte in

dem MESM für die

Merkmale α und γ;

 $m_{\alpha}^{ortho(n)}$ $m_{\gamma}^{ortho(n)}$

: iterative Näherungswerte für die gewünschten Randwerte

$$m_{\alpha}^{ortho}$$
, m_{γ}^{ortho} ; und

10 bα und by

: Konstanten

bezeichnen.

13. Verfahren nach Anspruch 1,

15 <u>dadurch gekennzeichnet</u>,

dass die mathematische Funktion folgende Gestalt hat:

$$\lambda_{\alpha}^{ortho(n+1)} = G(\lambda_{\alpha}^{ortho(n)}, m_{\alpha}^{ortho}, \dots)$$

$$= \lambda_{\alpha}^{ortho(n)} + t_{\alpha}^{ortho} \cdot \log \left(\frac{m_{\alpha}^{ortho}}{m_{\alpha}^{ortho(n)}} \cdot \frac{1 - \sum_{\beta \in Ai(n)} (t_{\beta} \cdot m_{\beta}^{ortho(n)})}{1 - \sum_{\beta \in Ai(n)} (t_{\beta} \cdot m_{\beta}^{ortho})} \right)$$



20 wobei:

n : der Iterationsparameter

Ai(n): eine in dem n'ten Iterationsschritt ausgewählte Merkmalsgruppe Ai(n) mit 1≤i≤m;

α : ein gerade betrachtetes Merkmal aus der gerade ausgewählten Merkmalsgruppe Ai(n); R

: alle Merkmale aus der Merkmalsgruppe Ai(n);

 t_{α}^{ortho} t_{β}^{ortho}

: die Größe eines Konvergenzschrittes mit

$$t_{\alpha}^{ortho} = t_{\beta}^{ortho} = 1/M_{i(n)}^{ortho}$$
 mit

$$M_{i(n)}^{ortho} = \max_{(h,w)} \left(\sum_{\beta \in Ai(n)} f_{\beta}^{ortho}(h,w) \right)$$

5

wobei $M_{i(n)}^{ortho}$ für binäre Funktionen f_{β}^{ortho} die maximale Anzahl von Funktionen aus der Merkmalsgruppe Ai(n) repräsentiert, welche für dasselbe Argument (h,w) den Wert 1 liefern;

 m_{α}^{ortho} m_{β}^{ortho}

: gewünschte orthogonalisierte Randwerte in dem MESM für die Merkmale α bzw. β ;

10

 $m_{\alpha}^{ortho(n)}$, $m_{\beta}^{ortho(n)}$: iterative Näherungswerte für die gewünschten Randwerte

$$m_{\alpha}^{ortho}$$
, m_{β}^{ortho} ;

wobei die Auswahl der Gruppe Ai(n) von Merkmalen α, deren zugehörige Parameter

λ^{ortho}
in einem aktuellen Iterationsschritt angepasst werden, entweder zyklisch oder nach einem vorgegebenen Kriterium erfolgt.



- 14. Spracherkennungssystem (10) mit:
- einer Erkennungseinrichtung (12) zum Erkennen des Bedeutungsinhaltes eines von einem Mikrophon (20) aufgenommenen und bereitgestellten akustischen Signals, insbesondere eines Sprachsignals, durch Abbilden von Teilen dieses Signals auf vordefinierte Erkennungssymbole, wie sie von dem implementierten Maximum Entropie Sprachmodell MESM angeboten werden, und zum Erzeugen von Ausgangssignalen, welche den erkannten Bedeutungsinhalt repräsentieren; und
- 25 einer Trainingseinrichtung (14) zum Anpassen des MESM an wiederkehrende statistische Muster in der Sprache eines bestimmten Benutzers des Spracherkennungssystems (10);

2.7

dadurch gekennzeichnet,

dass die Trainingseinrichtung (14) freie Parameter λ in dem MESM gemäß dem Verfahren nach Anspruch 1 berechnet.

15. Trainingseinrichtung (14) zum Anpassen des Maximum Entropie Sprachmodells MESM in einem Spracherkennungssystem (10) an wiederkehrende statistische Muster in der Sprache eines bestimmten Benutzers des Spracherkennungssystems (10), dadurch gekennzeichnet,

dass die Trainingseinrichtung (14) freie Parameter λ in dem MESM gemäß dem Verfahren 10 nach Anspruch 1 berechnet.



ZUSAMMENFASSUNG

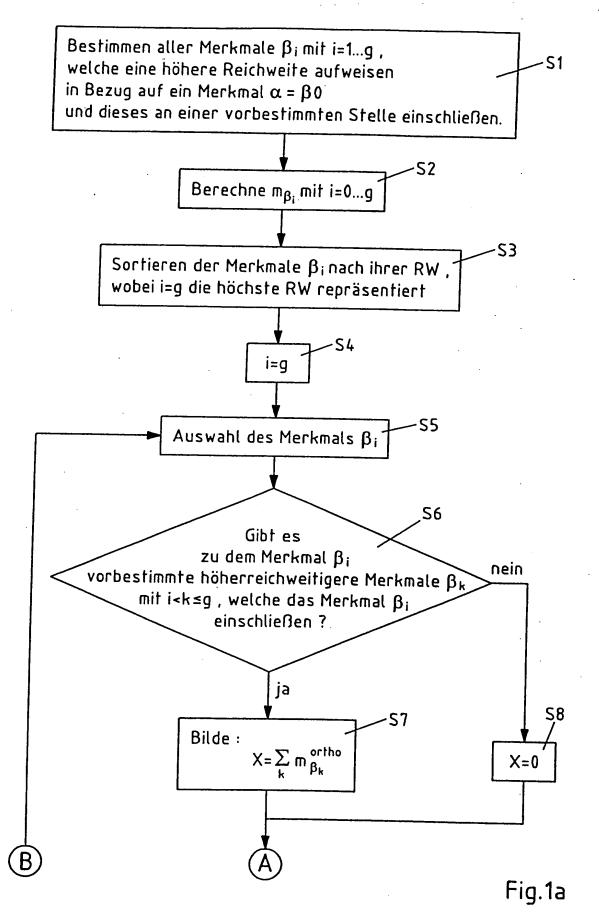
Spracherkennungssystem, Trainingseinrichtung und Verfahren zum iterativen Berechnen freier Parameter eines Maximum-Entropie-Sprachmodells

Die Erfindung betrifft ein Spracherkennungssystem und ein Verfahren zum iterativen

Berechnen freier Parameter λ_α eines Maximum-Entropie-Sprachmodells MESM mit Hilfe des Generalised-Iterative-Scaling-Trainingsalgorithmus in einem computergestützten Spracherkennungssystem gemäß der Formel λ_α στηρο(n+1) = G(λ_α στηρο(n), m_α στηρο, ...), wobei n einen Iterationsparameter, G eine mathematische Funktion, α ein Merkmal in dem MESM und m_α einen gewünschten orthogonalisierten Randwert in dem MESM für das 10 Merkmal α bezeichnet. Es ist die Aufgabe der Erfindung, das System und das Verfahren derart weiterzubilden, dass sie eine schnelle Berechnung des freien Parameters λ ohne Veränderung der ursprünglichen Trainingsaufgabe ermöglichen. Erfindungsgemäß wird diese Aufgabe dadurch gelöst, dass der gewünschte orthogonalisierte Randwert m_α στηρο στηρο durch Linearkombination des gewünschten Randwertes m_α mit gewünschten Randwerten 15 m_β von zu dem Merkmal α höher-reichweitigen Merkmalen β berechnet wird. Hierbei sind m_α und m_β gewünschte Randwerte der ursprünglichen Trainingsaufgabe.







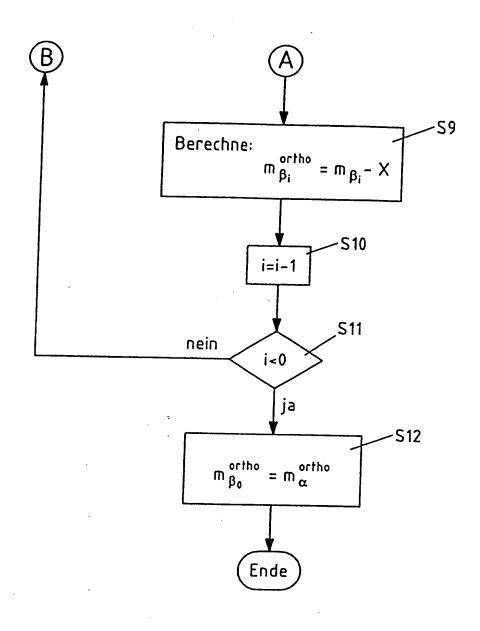
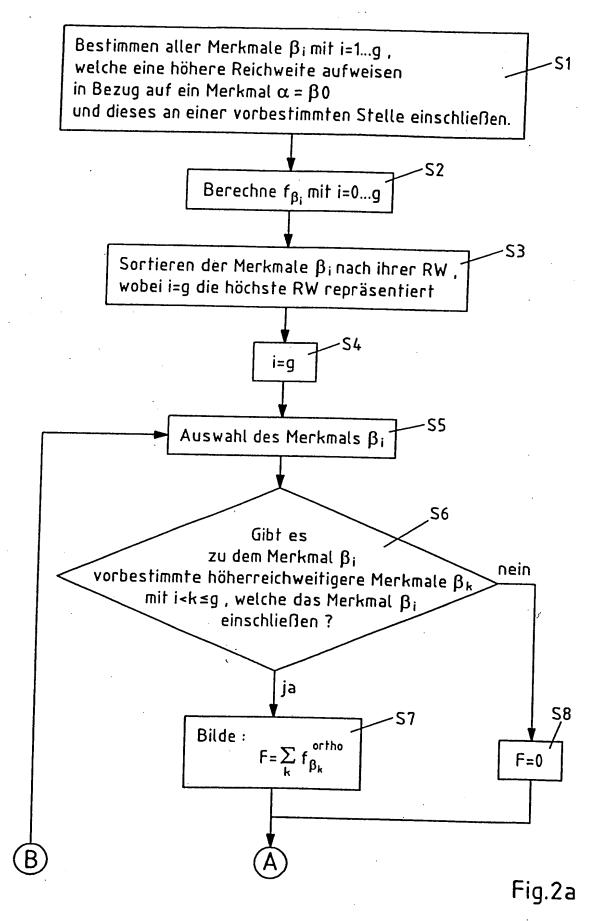


Fig.1b



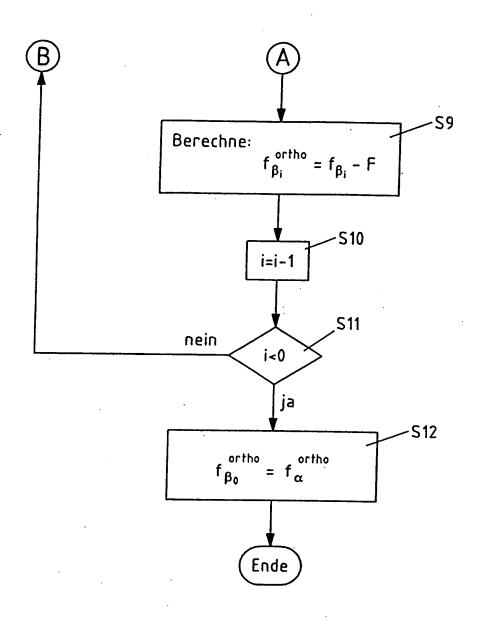


Fig.2b

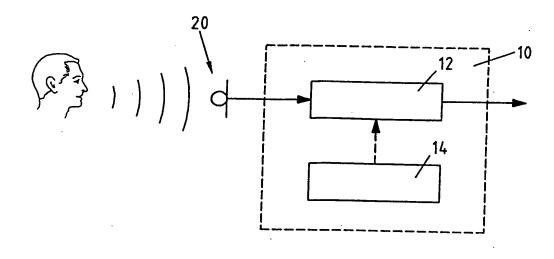


Fig.3

